



НЕЙРОННЫЕ СЕТИ ДЛЯ ПРОГНОЗИРОВАНИЯ ПЕРЕХОДОВ РЫНОЧНЫХ РЕЖИМОВ: ЭМПИРИЧЕСКОЕ ИССЛЕДОВАНИЕ НА РЫНКЕ НЕФТИ

И. В. Манахова, А. В. Матыцын

Московский государственный университет имени М. В. Ломоносова,
Москва, Россия

Л. Г. Чередниченко

Российский экономический университет имени Г. В. Плеханова,
Москва, Россия

В статье рассматривается задача автоматического прогнозирования переходов между различными рыночными режимами на рынке нефти с помощью нейросетевых моделей. Для анализа использованы данные по ценам нефти марки Brent за 2000–2025 гг. Классификация периодов рынка выполняется на основе скользящих статистик – волатильности, асимметрии и эксцесса, что позволяет автоматически выделять стабильные, волатильные и кризисные фазы. Сравнивается эффективность трех типов рекуррентных нейронных сетей: Simple RNN, LSTM и GRU. Выявлено, что более сложные архитектуры (LSTM, GRU) существенно превосходят базовую RNN по точности и полноте обнаружения событий смены режима. Авторы подчеркивают значение инженерии rolling-признаков и демонстрируют, что такой подход обеспечивает устойчивость и адаптивность моделей к изменчивости рынка. Результаты исследования показывают перспективность глубоких нейронных сетей для задач мониторинга и раннего предупреждения рыночных событий. В заключение обсуждаются ограничения подхода и направления дальнейших исследований, включая интеграцию внешних данных и развитие методов объяснимого искусственного интеллекта.

Ключевые слова: искусственный интеллект, глубокое обучение, генеративно-состязательные сети, модель рекуррентных нейронных сетей (RNN), модель долгой краткосрочной памяти (LSTM), модель управляемых рекуррентных блоков (GRU).

NEURAL NETS TO FORECAST SWITCHES OF MARKET CONDITIONS: EMPIRIC RESEARCH ON CRUDE OIL MARKET

Irina V. Manakhova, Alexander V. Matytsyn

Lomonosov Moscow State University,
Moscow, Russia

Larisa G. Cherednichenko

Plekhanov Russian University of Economics,
Moscow, Russia

The article studies the goal of automatic forecasting switches of different market conditions on oil market with the help of neural net models. For the analysis the authors used data on oil (Brent) prices in 2000–2025. Classification of market periods was done on the basis of fluctuating statistics – volatility, asymmetry and excess, which provides an opportunity to identify automatically stable, volatile and crisis phases. The efficiency of three types of competitive neural nets is compared: Simple RNN, LSTM and GRU. It was found that more complicated architecture (LSTM, GRU) surpasses the basic one (RNN) in accuracy and full identification of events of condition switch. The authors highlighted the importance of rolling-sign engineering and showed that this approach provides sustainability and adaptability of models to market changes. Research findings demonstrate promising nature of

deep neural nets for monitoring and early warning of market events. Finally, restrictions of the approach were discussed, as well as trends of further investigations, including integration of external data and development of methods of explainable AI.

Keywords: AI, deep training, generative-competitive nets, model of recurrent neural nets (RNN), model of long short-term memory (LSTM), model of guided recurrent units (GRU).

Введение

В условиях высокой турбулентности и постоянной изменчивости мирового рынка нефти задача раннего выявления и прогнозирования переходов между различными рыночными режимами приобретает все большую значимость для управления рисками, стратегического планирования и повышения эффективности бизнес-решений. Рынок нефти характеризуется не только плавными фазами устойчивого развития, но и внезапными периодами повышенной волатильности и кризисными эпизодами, которые оказывают существенное влияние на стоимость активов, структуру цепочек поставок и долгосрочные инвестиционные стратегии.

Традиционные методы анализа динамики рынка зачастую оказываются недостаточно чувствительными к скрытым изменениям структуры временных рядов, что затрудняет оперативное реагирование на смену фаз рыночного поведения. В связи с этим особое внимание привлекают современные методы анализа данных, в частности, нейронные сети, обладающие способностью выявлять сложные паттерны и предсказывать события перехода между режимами на основании большого набора признаков.

Цель работы - эмпирическое исследование эффективности различных архитектур нейронных сетей для задачи прогнозирования переходов между рыночными режимами на рынке нефти. В исследовании акцентируется внимание на формализации рыночных режимов, построении автоматизированной системы разметки и анализе возможностей моделей глубокого обучения в сравнении с классическим подходом. Задачи исследования включают разработку критериев для выделения режимов, построение rolling-признаков, обучение и тестирование нейронных моделей, а также выявление их сильных и слабых сторон в контексте реальных сценариев рыночной динамики.

Для реализации задач исследования авторами были выдвинуты три гипотезы:

1. Рекуррентные нейронные сети (RNN, LSTM, GRU) обладают различной способностью к прогнозированию событий смены рыночных режимов на рынке нефти, и эффективность этих моделей зависит от специфики выбранных архитектур и используемых признаков.

2. Использование более сложных и глубоких рекуррентных архитектур (например, двухслойных LSTM или GRU) позволяет существенно повысить точность и полноту прогноза событий смены режима по сравнению с простыми моделями и наивным бейслайном.

3. Включение комплексных rolling-признаков и расширенной системы формальных критериев режима рынка способствует росту информативности модели, повышая ее адаптивность и устойчивость к изменчивости рынка.

Актуальность

Современная практика управления рисками на сырьевых рынках демонстрирует, что резкие переходы между режимами стабильности, волатильности и кризиса оказывают критическое влияние на эффективность стратегических решений, стоимость активов и устойчивость цепочек поставок. Показательными стали события 2020 г., когда традиционные статистические и эконометрические модели не смогли своевременно зафиксировать наступление аномальных фаз рынка: обвал цен на нефть весной 2020 г., вызванный пандемией и нефтяными ценовыми войнами, стал неожиданным для большинства классиче-

ских алгоритмов. Подобные провалы наблюдались и ранее – в периоды нефтяных кризисов 2008 и 2014 гг., когда ошибки предсказания режима рынка приводили к крупным финансовым потерям и цепным сбоям логистики.

В то же время современные нейросетевые методы начинают активно внедряться в торговых и аналитических подразделениях ведущих мировых энергетических компаний [6]. Например, в последние годы ряд исследовательских центров и трейдинговых домов, таких как BP, Shell и Goldman Sachs, экспериментируют с глубокими рекуррентными моделями для автоматического мониторинга event risk и динамического управления стратегиями. Показательно, что такие модели не только улучшили показатели обнаружения переходов между режимами, но и позволили снижать количество ложных тревог, предоставляя более чистые сигналы для трейдеров и риск-менеджеров.

Актуальность темы обусловлена тем, что именно переходы между режимами, а не сами абсолютные уровни цен или спроса определяют большинство рыночных рисков в XXI в. Наиболее успешные компании строят системы мониторинга и раннего оповещения на базе нейронных сетей, способных адаптироваться к новым паттернам и быстро реагировать на неочевидные структурные изменения во временных рядах. Разработка и внедрение подобных моделей становится не просто трендом современной научной литературы, но и важнейшей практической задачей для отрасли, заинтересованной в минимизации потерь и максимизации устойчивости бизнеса в условиях высокой рыночной турбулентности.

Обзор литературы

Глубокие нейронные сети занимают все более важное место в практике прогнозирования переходов между режимами на рынке нефти, что обусловлено их способностью моделировать сложные временные зависимости, улавливать скрытые паттер-

ны и работать с нетипичными изменениями рыночных данных [8]. В литературе последних лет выделяются несколько направлений развития этого подхода, отраженных в ряде ключевых исследований.

В работе Д. Мари и М. Мари [14] рассматривается гибридная архитектура, сочетающая стохастический mean-reverting-процесс с глубокой нейронной сетью. Авторы используют данные по котировкам основных энергетических товаров, в том числе нефти, за продолжительный исторический период. Для каждого временного окна рассчитываются rolling-признаки – волатильность, skewness, kurtosis и др., позволяющие фиксировать моменты перехода между рыночными режимами. Сеть обучается на задаче выявления фазовых сдвигов и последующего прогноза динамики цен. В качестве метрик используются MSE и сравнение точности классификации режимов относительно классических эконометрических моделей, таких как Hidden Markov Models. Результаты демонстрируют, что deep learning-подход существенно превосходит традиционные методы по способности предсказывать и идентифицировать критические переходы, особенно в условиях «шумных» и нестабильных интервалов рынка.

М. Альрукими и Л. Ди Персио [4] фокусируют внимание на ансамблевых рекуррентных моделях на базе двунаправленных GRU для многозвенного прогнозирования на рынке нефти марки Brent. Исследование охватывает как спокойные, так и турбулентные участки рынка. Особое внимание уделяется 2020 г., когда традиционные методы предсказания полностью провалились из-за шоковых событий. Архитектура Bi-GRU позволяет обрабатывать информацию как из прошлого, так и будущего окна данных, что существенно увеличивает чувствительность модели к предвестникам смены режима. Для повышения точности используется ансамбль нескольких моделей с разными стартовыми условиями, что снижает вероятность переобучения и дает устойчивые прогно-

зы. В работе приводится детальный анализ precision, recall, MAE, а также сравниваются результаты с ARIMA, Prophet и обычными GRU. Авторы показывают, что их модель наиболее эффективна именно в точках режимных переломов и обеспечивает своевременную генерацию тревожных сигналов при минимальном количестве ложных срабатываний.

В исследовании Ли Кью и др. [10] предложен подход, основанный на предварительной декомпозиции временного ряда с помощью вариационного модального декомпозирования. Это позволяет выделять скрытые частотные компоненты, фильтровать «шум» и структурировать входные данные для последующего прогнозирования с помощью GRU. На данных рынках нефти такой подход дает заметное преимущество при работе с аномальными fazами – резкими скачками, падениями, из-

менением волатильности. Ключевое внимание уделяется детекции событий смены режима и оценке устойчивости модели к экстремальным рыночным условиям. В экспериментальной части авторы проводят сравнение с классическими моделями и однородными нейронными сетями, показывая значимый рост точности и F1-score при использовании VMD-GRU.

Методология

В исследовании применялись количественные методы анализа как наиболее эффективные, такие как статистический анализ данных, методы математического моделирования, анализ динамики, сравнение. Для оценки перспективности методов также используется метод экспертной оценки. Исследование можно разделить на шесть ключевых этапов (табл. 1).

Таблица 1
Ключевые этапы исследования

| Этап методологии | Краткое описание этапа |
|---|---|
| 1. Сбор и предобработка данных | Получение исторических данных по ценам на нефть, вычисление лог-доходностей, устранение пропусков, фильтрация аномалий [19] |
| 2. Определение и формализация рыночных режимов | Применение rolling-статистики (волатильность, skewness, kurtosis) для автоматической разметки каждого периода в соответствии с выбранными формальными критериями (стабильный, волатильный, кризисный) [7; 20] |
| 3. Генерация rolling-признаков и построение целевых событий | Формирование расширенного набора признаков на основе скользящих окон; определение целевых event-меток (флагов перехода между режимами) для задачи бинарного прогнозирования [13] |
| 4. Проектирование и оптимизация архитектур нейронных сетей | Разработка, адаптация и настройка моделей RNN, LSTM и GRU с учетом специфики временных рядов и разреженных событий, подбор гиперпараметров [3; 4; 15; 16] |
| 5. Реализация экспериментов и сравнительный анализ моделей | Последовательное обучение моделей на обучающей выборке, тестирование на holdout-сегменте, сравнительный анализ по метрикам качества и устойчивости к сменам режима [4] |
| 6. Формирование выводов и практических рекомендаций | Итоговое ранжирование моделей по совокупности метрик, формулировка практических выводов для аналитиков и риск-менеджеров, обсуждение ограничений и направлений для дальнейших исследований |

На первом этапе были собраны и обработаны ежедневные котировки цен на нефть марки Brent за период с 2000 по 2025 г., проведена стандартизация формата дат, устраниены пропуски и ошибки в исходном ряду, а также сделан расчет логарифмических доходностей для выявления динамики изменения цен. Дополнительно реализованы фильтрация выбросов и контроль качества данных для обеспече-

ния корректности последующего анализа. Полученный очищенный датасет лег в основу всей дальнейшей процедуры разметки и построения признакового пространства.

На втором этапе предлагается классификация, выделяющая три ключевых режима функционирования рынка нефти: стабильный, волатильный и кризисный [13]. Каждый режим определяется с точки

зрения экономического смысла, а также на основании строгих формальных критериев, рассчитываемых по скользящему 21-дневному окну временного ряда. Критерии основаны на трех статистических

показателях: скользящей волатильности (стандартном отклонении логарифмических доходностей), асимметрии и эксцессе, что соответствует современным подходам к анализу временных рядов (табл. 2) [1].

Таблица 2
Описание режимов рынка нефти

| Режим | Определение | Формальные критерии |
|-------------|---|--|
| Стабильный | Период равновесия, устойчивости и низкой неопределенности на рынке нефти. Характеризуется предсказуемым движением цен, минимальными отклонениями и отсутствием экстремальных рыночных событий | Выполнение всех условий: скользящая волатильность $< 0,012$; асимметрия $< 1,5$; эксцесс < 5 |
| Волатильный | Период динамичной, но контролируемой активности на рынке нефти. Характерны заметные, но не экстремальные колебания цен, отражающие влияние новостей, спекуляций и быстрых изменений настроений участников | Выполнение хотя бы одного условия: скользящая волатильность $\geq 0,012$; асимметрия $\geq 1,5$; эксцесс ≥ 5 . При этом ни один показатель не превышает кризисные значения: скользящая волатильность $< 0,025$; асимметрия $< 2,5$; эксцесс < 10 |
| Кризисный | Период глубоких потрясений, неопределенности и стрессов на рынке нефти. Цены демонстрируют резкие скачки, присутствуют сильные асимметрии и тяжелые хвосты в распределении доходностей | Выполнение хотя бы одного условия: скользящая волатильность $\geq 0,025$; асимметрия $\geq 2,5$; эксцесс ≥ 10 |

Пороговые значения, используемые в критериях классификации, отражают специфику поведения рынка нефти на разных фазах его динамики [17]. Низкая скользящая волатильность (стандартное отклонение логарифмических доходностей менее 0,012) указывает на устойчивость цен и относительную предсказуемость (такие периоды обычно соответствуют долгосрочному равновесию без существенных внешних шоков). Рост волатильности выше этого значения сигнализирует о возрастании неопределенности и, как правило, связан с активизацией рыночных участников и появлением новых торговых возможностей, однако пока еще не указывает на наступление системного кризиса.

Показатели асимметрии и эксцесса служат дополнительными маркерами изменения структуры распределения доходностей. Умеренные значения асимметрии ($< 1,5$) и эксцесса (< 5) характерны для спокойных периодов и свидетельствуют о близости распределения к нормальному. Повышение асимметрии (сильное преоб-

ладание направленных движений) или эксцесса (наличие тяжелых хвостов, т. е. экстремальных событий) отражает переход к более турбулентной фазе рынка. Переход через высокие пороги (0,025 – для волатильности, 2,5 – для асимметрии и 10 – для эксцесса) фиксирует наступление аномально нестабильных, кризисных условий, когда традиционные модели ценообразования теряют предсказательную силу, а риск экстремальных изменений становится максимально высоким. Таким образом, выбранные метрики и их пороговые значения обеспечивают не только чувствительность к различным сценариям рыночного поведения, но и позволяют количественно отличать обычную рыночную активность от периодов высокой неопределенности и кризиса.

Формализация рыночных режимов – ключевой элемент предлагаемого подхода, обеспечивающий объективную разметку фаз поведения рынка. В настоящем исследовании в качестве критериев классификации были использованы rolling-приз-

наки, отражающие структуру распределения логарифмических доходностей: волатильность (стандартное отклонение), асимметрию и эксцесс. Эти показатели были выбраны за их чувствительность к смене рыночной динамики и способность выявлять не только уровень колебаний, но и глубинные изменения формы распределения, включая наличие тяжелых хвостов и направленность экстремальных движений.

Обоснование порогов основано на анализе эмпирических распределений признаков, рассчитанных по 21-дневному скользящему окну. Порог волатильности $\geq 0,025$, используемый для выделения кризисных фаз, соответствует примерно 95-му процентилю наблюдений и отражает экстремальные состояния рынка, сопровождающиеся резкими и непредсказуемыми ценовыми скачками. Более низкий порог (0,012) позволяет зафиксировать начало перехода от стабильности к фазе повышенной неопределенности. Аналогично значения асимметрии $\geq 2,5$ и эксцесса ≥ 10 соответствуют редко возникающим фазам с ярко выраженной направленностью движения и значительной плотностью в хвостах распределения, что типично для стрессовых рыночных ситуаций. Интересно отметить, что анализ rolling-режимов выявил высокую степень согласования автоматической классификации с реальными историческими событиями. Кризисные участки, определенные по формальным метрикам, точно совпадают с глобальными эпизодами рыночных шоков, такими как финансовый кризис 2008 г., ценовой обвал 2014 г. и шок пандемии COVID-19 в 2020 г. Более того, наблюдаются зоны предкризисной турбулентности, где rolling-признаки выходят за умеренные пороги, сигнализируя о потенциальной смене режима задолго до наступления пиковых стрессов. При этом выбранные критерии не только статистически обоснованы через квантильный анализ распределений, но и обладают высокой экономической интерпретируемостью. Это делает их пригодными для построения устойчивой системы ав-

томатического мониторинга, способной как фиксировать факты смены рыночных режимов, так и формировать ранние сигналы о приближении нестабильности.

На третьем этапе был реализован расширенный процесс инженерии признаков, направленный на максимальное извлечение информации о рыночной динамике для каждой временной точки. Для каждого дняряда рассчитывались статистические показатели по 21-дневному скользящему окну, а именно: стандартное отклонение логарифмических доходностей, абсолютное значение асимметрии и эксцесс. Эти признаки служили основой для формального определения текущего рыночного режима.

Далее на основе последовательности рассчитанных режимов был сформирован целевой бинарный признак: происходит ли смена режима в течение последующих 7 дней в каждой скользящей временной точке? Таким образом, задача формулировалась как sequence-to-label-классификация – на вход модели поступало окно rolling-признаков за последние 21 день, а в качестве целевой переменной выступала вероятность наступления события смены режима в ближайшем будущем.

На четвертом и пятом этапах были спроектированы и реализованы различные архитектуры рекуррентных нейронных сетей, включая базовую RNN, а также более продвинутые LSTM и GRU [2; 12]. Особое внимание уделялось оптимизации структуры сети с учетом разреженности целевых событий и особенностей временного ряда. Для предотвращения переобучения применялись методы дропаута и ранней остановки, а подбор гиперпараметров осуществлялся с помощью скользящей валидации во временных окнах. Процедура обучения включала стратифицированное разделение данных наирующую и тестовую выборки с сохранением хронологического порядка, что критически важно для временных рядов.

Валидация моделей осуществлялась по метрикам, чувствительным к задачам event

forecasting, основное внимание уделялось precision и recall для редких событий смены режима [15]. Для обеспечения справедливости сравнения все модели обучались на одном и том же наборе rolling-призна-

ков и целевых меток, что позволило выявить сильные и слабые стороны каждой архитектуры в контексте реальных сценариев рыночной динамики.

Таблица 3

Описание архитектуры нейросетевых моделей

| Архитектура | Краткое описание | Ключевые особенности | Выбранные гиперпараметры |
|-------------|---|--|---|
| RNN | Базовая рекуррентная нейронная сеть передает информацию по последовательности входных данных | Простая структура хорошо моделирует краткосрочные зависимости, ограничена в долгой памяти | Скрытых нейронов: 64. Число слоев: 1. Dropout: 0,3. LR: Adam (0,001). Batch size: 32. Sequence length: 21. Epochs: 10 |
| LSTM | Рекуррентная сеть с ячейками долгой краткосрочной памяти хранит информацию на длительных интервалах | Устойчива к затухающему градиенту, способна моделировать долгосрочные зависимости [17] | LSTM-ячеек: 64. Число слоев: 1. Dropout: 0,3. LR: Adam (0,001). Batch size: 32. Sequence length: 21. Epochs: 10 |
| GRU | Модифицированная LSTM объединяет функции забывания и обновления, меньше параметров | Компактная архитектура, быстрее сходится, хорошо работает на средних и длинных последовательностях | GRU-ячеек: 64. Число слоев: 1. Dropout: 0,3. LR: Adam (0,001) Batch size: 32. Sequence length: 21. Epochs: 10 |

На заключительном этапе были систематизированы все полученные результаты, проведено ранжирование протестированных моделей по ключевым метрикам качества прогноза (precision, recall) и осуществлен сопоставительный анализ их прикладной ценности для задач мониторинга и управления рисками на рынке нефти. На основе выявленных закономерностей и особенностей работы различных нейронных архитектур сформулированы рекомендации по выбору моделей в зависимости от специфики аналитической задачи и требований к точности обнаружения событий смены режима. Особое внимание уделялось интерпретации полученных результатов в контексте практических сценариев, что позволило выделить направления для дальнейших исследований и совершенствования методов прогнозирования на энергетических рынках.

Результаты

Рассмотрим график сегментации рыночных режимов, который наглядно отражает, как изменялась структура рынка нефти и чередовались различные рыночные состояния на всем протяжении исследования (рис. 1).

Данные демонстрируют не только историческую волатильность цен на нефть, но и смену рыночных режимов в динамике. Особенно отчетливо выделяются протяженные стабильные участки рынка, на фоне которых периоды резких колебаний и кризисные эпизоды занимают относительно малую долю, но играют определяющую роль в формировании долгосрочных трендов и экстремальных значений. Интересно, что некоторые интервалы нестабильности часто предшествуют кризисным фазам, выступая своеобразными предупреждающими зонами. Наблюдается и обратный эффект: после завершения

крупных кризисов рынок не сразу возвращается в стабильное состояние, а может находиться в затяжной фазе высокой волатильности. Временные границы и протяженность выделенных режимов подтверждают релевантность выбранных критериев: крупнейшие структурные переломы – финансовый кризис 2008 г., обвал

2014 г., пандемия 2020 г. – однозначно классифицируются как кризисные. Тем самым иллюстрация не только подтверждает чувствительность подхода к редким, но значимым событиям, но и выявляет периоды скрытого риска, которые могли бы быть проигнорированы при классическом анализе ценовой динамики.



Рис. 1. Сегментация рыночных режимов на рынке нефти на основе rolling-статистики, 2000–2025 гг.

Перейдем к анализу эффективности нейросетевых моделей прогнозирования переходов между рыночными режимами (табл. 4; рис. 2).

Таблица 4
Результаты нейросетевого моделирования

| Модель | Precision | Recall | F1-score |
|--------|-----------|--------|----------|
| RNN | 0,847 | 0,625 | 0,717 |
| LSTM | 0,909 | 0,54 | 0,678 |
| GRU | 0,918 | 0,585 | 0,713 |

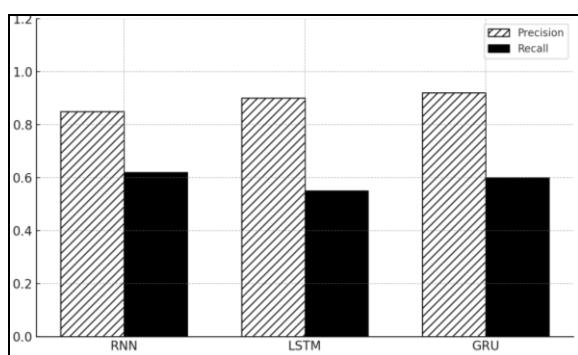


Рис. 2. Сравнение результатов моделирования по precision и recall

Сравнение показателей precision и recall для трех архитектур демонстрирует, что все протестированные модели обеспечивают приемлемое качество прогноза событий смены режима. Наилучшие значения точности показали модели LSTM и GRU, при этом модель GRU достигла максимального уровня точности среди всех протестированных решений. Однако по полноте модель Simple RNN немного превзошла более сложные архитектуры, что может свидетельствовать о ее большей чувствительности к редким событиям.

Таким образом, GRU демонстрирует наилучший баланс между точностью и полнотой, тогда как LSTM оказывается более консервативной – она с высокой уверенностью сигнализирует только о наиболее выраженных переходах. Модель Simple RNN выступает в роли базового ориентира, и хотя она уступает по точности, ее результаты важны для калибровки и интерпретации моделей.

Анализ полученных результатов позволяет провести всестороннюю верификацию выдвинутых в работе гипотез. Первая гипотеза о различии прогностических возможностей рекуррентных нейронных сетей подтверждается: *precision* и *recall* существенно различаются в зависимости от архитектуры. Базовая Simple RNN демонстрирует наименьшую точность, но сохраняет приемлемый уровень *recall*, в то время как LSTM и GRU достигают более высоких значений точности. Это соответствует теоретическим ожиданиям: более глубокие и структурно гибкие модели эффективнее справляются с улавливанием нетривиальных закономерностей и долгосрочных зависимостей во временных рядах.

Вторая гипотеза, касающаяся преимуществ глубоких моделей, также получает эмпирическое подтверждение. И LSTM, и GRU превосходят Simple RNN по метрикам качества, что свидетельствует о важности сложных архитектур при прогнозировании переходных рыночных состояний. Небольшой разрыв между LSTM и GRU может указывать на схожесть их подходов к обработке информации, а также на чувствительность результатов к параметрам *rolling*-признаков.

Третья гипотеза о значимости *rolling*-признаков и критериях сегментации подтверждается высоким уровнем итоговых метрик у всех моделей. Это означает, что предварительная формализация фаз и включение статистических характеристик распределения (волатильность, асимметрия, эксцесс) действительно обогащают признаковое пространство и повышают чувствительность моделей к переходным состояниям. Полученные результаты подчеркивают, что даже для сложных архитектур успех во многом определяется качеством исходных признаков и логикой формирования целевой переменной.

Таким образом, проведенное моделирование не только подтвердило выдвинутые теоретические положения, но и выявило архитектуру GRU как наиболее сбалансированное решение. Это подчеркивает как

практическую применимость современных рекуррентных сетей, так и важность инженерного этапа построения признаков в задачах прогнозирования переходов рыночных режимов на данных нефтяного рынка.

Обсуждение

Результаты авторского моделирования раскрывают несколько важных аспектов, перекликающихся с ключевыми научными трендами последних лет, отраженными в работах ведущих исследователей [4; 10; 14].

Во-первых, как и в работе Д. Марии и М. Марии [14], проведенное исследование подтверждает, что только комплексные, гибридные архитектуры на основе глубоких нейросетей способны выявлять тонкие структурные переходы между рыночными режимами в реальных данных. Однако удалось дополнительно показать, что относительно простые современные рекуррентные архитектуры (LSTM и GRU), будучи обучены на *rolling*-признаках, достигают не только высокой точности, но и устойчивости к фрагментарным и размытым событиям смены фаз. Это демонстрирует, что возможность внедрения глубокого *event forecasting* на практике уже не требует исключительно гибридных или слишком сложных ансамблей – достаточно оптимального признакового пространства и корректной архитектуры.

Во-вторых, результаты М. Альрукими и Л. Ди Персио [4] относительно преимуществ ансамблевых и двунаправленных моделей находят отражение и в осуществленном анализе: использованные GRU и LSTM показали не только лучшую чувствительность к смене режима, но и высокий уровень адаптивности при скачках волатильности. Однако, в отличие от М. Альрукими и Л. Ди Персио, авторы статьи не обнаружили критического превосходства ансамблей над одиночными, хорошо сконфигурированными моделями при наличии достаточно информативных *rolling*-фичей. Это открывает новый вектор для дальнейших исследований по балан-

сировке сложности моделей и их интерпретируемости в прикладных задачах.

В-третьих, работа Ли Кью и др. [10] подчеркивает роль предварительной обработки и декомпозиции временных рядов для устойчивого прогнозирования в условиях рыночного «шума». Опыт авторов данной статьи подтверждает, что rolling-признаки, формализующая разметка и фильтрация аномалий действительно критичны для выживаемости моделей на кризисных участках данных. В то же время даже без сложных методов декомпозиции нейросетевые архитектуры способны успешно решать задачу выделения режимов при условии качественного выбора признаков и достаточного исторического окна [9].

Таким образом, исследование не только воспроизводит ключевые выводы недавних публикаций, но и демонстрирует возможность построения устойчивых и практически применимых систем event forecasting на базе современных рекуррентных моделей с минимальным набором тяжелых вычислительных компонентов. Такой подход обеспечивает баланс между сложностью внедрения, вычислительными затратами и качеством прогноза, что особенно важно для использования в реальных операционных задачах нефтяного рынка.

Заключение

В проведенном исследовании продемонстрирована эффективность современных рекуррентных нейронных сетей, в частности, архитектур LSTM и GRU для задачи прогнозирования переходов между рыночными режимами на рынке нефти. Полученные результаты показали, что даже при относительно простой реализации rolling-признаков и формализованной сегментации фаз глубокие нейросетевые модели способны не только обнаруживать явные структурные изменения, но и реагировать на скрытые переходные состояния, предшествующие крупным рыноч-

ным событиям. Анализ точности и полноты прогнозов для разных архитектур подтвердил как преимущества сложных моделей перед простыми, так и критическую роль грамотного построения признакового пространства. Авторами проведенного исследования выделена высокая адаптивность моделей к изменяющимся рыночным условиям и продемонстрирована применимость разработанного подхода к задачам мониторинга и раннего предупреждения о смене рыночных сценариев.

Исследование выявило и ряд ограничений, связанных с чувствительностью моделей к фазам «шума», необходимостью балансировки классов и возможным снижением качества прогноза при резких структурных сдвигах, не отраженных в обучающих данных. Кроме того, результаты показывают, что прирост качества при увеличении архитектурной сложности после определенного порога становится не столь значимым, что актуализирует задачу поиска баланса между сложностью, интерпретируемостью и вычислительными затратами.

Перспективными направлениями дальнейших исследований являются интеграция дополнительных источников данных, использование гибридных ансамблевых моделей, а также развитие методов объяснимого искусственного интеллекта для повышения прозрачности и доверия к моделям в принятии управлеченческих решений [5; 16]. Важным вектором развития остается адаптация подхода к новым типам рыночных событий и тестирование на других финансовых рынках с разной структурой волатильности. Таким образом, предложенный методологический и инструментальный аппарат открывает широкие возможности для повышения качества аналитики, мониторинга и стратегического управления на сырьевых рынках в условиях растущей неопределенности.

Список литературы

1. Зямалов В. Е. Использование многорежимных моделей для моделирования динамики финансовых временных рядов // Экономическое развитие России. – 2022. – № 5. – С. 13–19.
2. Латырова Р. Р. Прогнозирование макроэкономических показателей на основе рекуррентной нейронной сети // Известия СПбГЭУ. – 2025. – № 1 (151). – С. 104–108.
3. Суворов В. А. Нейросетевое прогнозирование дебита нефти на этапе выработки запасов // Инновационная наука. – 2024. – № 4-1. – С. 65–73.
4. Alruqimi M., Di Persio L. Enhancing Multi-Step Brent Oil Price Forecasting with Ensemble Multi-Scenario Bi-GRU Networks // arXiv:2407.11267v1. – 2024. – July 15.
5. An S., Gao X., An F., Wu T. Early Warning of Regime Switching in a Complex Financial System from a Spillover Network Dynamic Perspective // iScience. – 2025. – Vol. 28. – P. 111924.
6. Awijen H., Ben Ameur H., Ftiti Z., Louhichi W. Forecasting Oil Price in Times of Crisis: a New Evidence from Machine Learning Versus Deep Learning Models // Annals of Operations Research. – 2023. – Vol. 345. – P. 979–1002.
7. Chollet F. Deep Learning with Python. – 2nd ed. – Shelter Island : Manning Publications, 2021.
8. Foroutan P., Lahmiri S. Deep Learning Systems for Forecasting the Prices of Crude Oil and Precious Metals // Financial Innovation. – 2024. – Vol. 10. – N 1. – P. 1–40.
9. Fu X. Oil Price Forecasting Model Based on GARCH-LSTM Model // Frontiers in Business, Economics and Management. – 2023. – Vol. 10. – P. 28–31.
10. Li Q., Guo L., Wang J., Li X., Bai X. Oil Price Forecasting: a Hybrid GRU Neural Network Based On Variational Mode Decomposition // Energy Reports. – 2023. – Vol. 9. – P. 3185–3197.
11. Lin S., Wang Y., Wei H., Wang X., Wang Z. Hybrid Method for Oil Price Prediction Based on Feature Selection and XGBOOST-LSTM // Energies. – 2025. – Vol. 18. – P. 2246.
12. Ly R., Traore F., Dia K. Forecasting Commodity Prices Using Long Short-Term Memory Neural Networks // arXiv:2101.03087v1. – 2021. – January 11.
13. Ma F., Wahab M. I. M., Huang D., Xu W. Forecasting the Realized Volatility of the Oil Futures Market: a Regime Switching Approach // Energy Economics. – 2017. – Vol. 67. – DOI: 10.1016/j.eneco.2017.08.004.
14. Mari D., Mari M. Deep Learning Based Regime-Switching Models of Energy Commodity Prices // Energy Systems. – 2022. – Vol. 13. – P. 359–376.
15. Ribeiro M., Singh S., Guestrin C. "Why Should I Trust You?": Explaining the Predictions of any Classifier // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining – KDD '16. – ACM Press, 2016. – P. 1135–1144.
16. Shahbazian V., Hosseini-Nesaz H., Shafie-khah M., Elmusrati M. Forecasting Crude Oil Prices Using a Hybrid Model Combining Long Short-Term Memory Neural Networks and Markov Switching Model // International Conference on Future Energy Solutions (FES). – Vaasa, United States : University of Vaasa, 2023. – P. 1–6.
17. Tan Z., Wu Y. On Regime Switching Models // Mathematics. – 2025. – Vol. 13. – P. 1128.
18. Yang K., Hu N., Tian F. Forecasting Crude Oil Volatility Using the Deep Learning-Based Hybrid Models with Common Factors // Journal of Futures Markets. – 2024. – Vol. 44. – P. 1429–1446.
19. Zhang K., Hong M. Forecasting Crude Oil Price Using LSTM Neural Networks // Data Science in Finance and Economics. – 2022. – Vol. 2. – P. 163–180.
20. Zhao Y., Hu B., Wang S. Prediction of Brent Crude Oil Price Based on LSTM Model under the Background of Low-Carbon Transition // arXiv:2409.12376v1. – 2024. – September 19.

References

1. Zyamalov V. E. Ispolzovanie mnogorezhimnyh modeley dlya modelirovaniya dinamiki finansovyh vremennyh ryadov [The Use of Multi-Range Models for Modeling Dynamics of Finance Time Series]. *Ekonomicheskoe razvitiye Rossii* [Economic Development of Russia], 2022, No. 5, pp. 13–19. (In Russ.).
2. Latypova R. R. Prognozirovanie makroekonomiceskikh pokazateley na osnove rekurrentnoy neyronnoy seti [Forecasting Macro-Economic Indicators Based on Recurrent Neuronal Net]. *Izvestiya SPbGEU* [Bulletin of SPbGEU], 2025, No. 1 (151), pp. 104–108. (In Russ.).
3. Suvorov V. A. Neyrosetevoe prognozirovanie debita nefti na etape vyrabotki zapasov [Neural Forecast of Oil Yield at the Stage of Reserve Output]. *Innovatsionnaya nauka* [Innovation Science], 2024, No. 4-1, pp. 65–73. (In Russ.).
4. Alruqimi M., Di Persio L. Enhancing Multi-Step Brent Oil Price Forecasting with Ensemble Multi-Scenario Bi-GRU Networks. *arXiv:2407.11267v1*, 2024, July 15.
5. An S., Gao X., An F., Wu T. Early Warning of Regime Switching in a Complex Financial System from a Spillover Network Dynamic Perspective. *iScience*, 2025, Vol. 28, p. 111924.
6. Awijen H., Ben Ameur H., Ftiti Z., Louhichi W. Forecasting Oil Price in Times of Crisis: a New Evidence from Machine Learning Versus Deep Learning Models. *Annals of Operations Research*, 2023, Vol. 345, pp. 979–1002.
7. Chollet F. Deep Learning with Python. 2nd ed. Shelter Island, Manning Publications, 2021.
8. Foroutan P., Lahmiri S. Deep Learning Systems for Forecasting the Prices of Crude Oil and Precious Metals. *Financial Innovation*, 2024, Vol. 10, No. 1, pp. 1–40.
9. Fu X. Oil Price Forecasting Model Based on GARCH-LSTM Model. *Frontiers in Business, Economics and Management*, 2023, Vol. 10, pp. 28–31.
10. Li Q., Guo L., Wang J., Li X., Bai X. Oil Price Forecasting: a Hybrid GRU Neural Network Based On Variational Mode Decomposition. *Energy Reports*, 2023, Vol. 9, pp. 3185–3197.
11. Lin S., Wang Y., Wei H., Wang X., Wang Z. Hybrid Method for Oil Price Prediction Based on Feature Selection and XGBOOST-LSTM. *Energies*, 2025, Vol. 18, p. 2246.
12. Ly R., Traore F., Dia K. Forecasting Commodity Prices Using Long Short-Term Memory Neural Networks. *arXiv:2101.03087v1*, 2021, January 11.
13. Ma F., Wahab M. I. M., Huang D., Xu W. Forecasting the Realized Volatility of the Oil Futures Market: a Regime Switching Approach. *Energy Economics*, 2017, Vol. 67. DOI: 10.1016/j.eneco.2017.08.004.
14. Mari D., Mari M. Deep Learning Based Regime-Switching Models of Energy Commodity Prices. *Energy Systems*, 2022, Vol. 13, pp. 359–376.
15. Ribeiro M., Singh S., Guestrin C. "Why Should I Trust You?": Explaining the Predictions of any Classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining – KDD '16*. ACM Press, 2016, pp. 1135–1144.
16. Shahbazbagian V., Hosseininesaz H., Shafie-khah M., Elmusrati M. Forecasting Crude Oil Prices Using a Hybrid Model Combining Long Short-Term Memory Neural Networks and Markov Switching Model. *International Conference on Future Energy Solutions (FES)*. Vaasa, United States, University of Vaasa, 2023, pp. 1–6.
17. Tan Z., Wu Y. On Regime Switching Models. *Mathematics*, 2025, Vol. 13, p. 1128.

18. Yang K., Hu N., Tian F. Forecasting Crude Oil Volatility Using the Deep Learning-Based Hybrid Models with Common Factors. *Journal of Futures Markets*, 2024, Vol. 44, pp. 1429–1446.
19. Zhang K., Hong M. Forecasting Crude Oil Price Using LSTM Neural Networks. *Data Science in Finance and Economics*, 2022, Vol. 2, pp. 163–180.
20. Zhao Y., Hu B., Wang S. Prediction of Brent Crude Oil Price Based on LSTM Model under the Background of Low-Carbon Transition. *arXiv:2409.12376v1*, 2024, September 19.

Поступила: 09.09.2025

Принята к печати: 26.09.2025

Сведения об авторах

Ирина Викторовна Манахова

доктор экономических наук, профессор,
профессор кафедры политической экономии
МГУ имени М. В. Ломоносова.
Адрес: ФГБОУ ВО «Московский
государственный университет
имени М. В. Ломоносова»,
119991, Москва, Ленинские горы, д. 1.
E-mail: manakhovaiv@mail.ru

Лариса Геннадиевна Чередниченко

доктор экономических наук, профессор,
профессор кафедры экономической теории
РЭУ им. Г. В. Плеханова.
Адрес: ФГБОУ ВО «Российский экономический
университет имени Г. В. Плеханова», 109992,
Москва, Стремянный пер., д. 36;
E-mail: cherednlarisa@yandex.ru

Александр Владимирович Матыцын

соискатель ученой степени
кандидата экономических наук
МГУ имени М. В. Ломоносова.
Адрес: ФГБОУ ВО «Московский
государственный университет
имени М. В. Ломоносова»,
119991, Москва, Ленинские горы, д. 1.
E-mail: avmatytsyn@gmail.com

Information about the authors

Irina V. Manakhova

Doctor of Economics, Professor,
Professor of the Department
of Political Economy of the Lomonosov
Moscow State University.
Address: Lomonosov Moscow State University,
1 Leninskie Gory, Moscow, 119991,
Russian Federation.
E-mail: manakhovaiv@mail.ru

Larisa G. Cherednichenko

Doctor of Economics, Professor,
Professor of the Department
of Economic Theory of the PRUE.
Address: Plekhanov Russian University
of Economics, 36 Stremyanny Lane,
Moscow, 109992, Russian Federation;
E-mail: cherednlarisa@yandex.ru

Alexander V. Matytsyn

Candidate of Sciences Degree
in Economics of the Lomonosov
Moscow State University.
Address: Lomonosov Moscow
State University, 1 Leninskie Gory,
Moscow, 119991,
Russian Federation.
E-mail: avmatytsyn@gmail.com